



TITLE:

Limited Processor Sharing Queues

AUTHOR(S):

山崎, 源治; 逆瀬川, 浩孝

CITATION:

山崎, 源治 ...[et al]. Limited Processor Sharing Queues. 数理解析研究所
講究録 1984, 519: 99-113

ISSUE DATE:

1984-04

URL:

<http://hdl.handle.net/2433/98430>

RIGHT:

Limited Processor Sharing Queues

工学院大 山崎 源治 (Genji Yamazaki)

筑波大 逆瀬川 浩孝 (Hirolaka Sakasegawa)

1. はじめに

外部から到着するジョブを処理する場合、1人のサーバを配するか、その $1/m$ の能力を持つ m 人 ($m \geq 2$) のサーバを配すべきか、という問題は、待ち行列論で古くからよく議論されてきた問題の1つである。もちろん、 m -サーバシステムでの“待ち”の解析は非常に難しいため、単一サーバとの定量的比較ができるのは、ごく限られた場合のみである。しかしながら、単一サーバシステムでは、システム内に1つでもジョブが存在するときは常にそのサービス能力をフルに使うが、 m -サーバシステムでは、システム内に m 以上のジョブが存在するときのみそのサービス能力をフルに使うが、ジョブ数が m 未満のときはその1部のみを使うことから、直観的には、“待ち” (ジョブの列待ち時間ではなく、その系内滞留時間などシステム全体に関するもの) からみて、単一サーバシステムのほうが有効であると考えられる。

この観点から、Stidham [3] は、単一サーバシステムと m -サーバシステムの系内人数分布の比較を試み（両システムの利用率は等しいという条件で）、ジョブのサービス時間がアーラン二分布に従う場合、単一サーバの系内人数は m -サーバのそれよりも確率的に小さい（単一サーバの有効性）を示した。この結果はより一般的なサービス時間分布のもとでも成立しそうであるが、サービス時間の変動係数が 1 以上のときには反例が提出されていて（Brumelle [1]）、上述の結果が成立するサービス時間の分布のクラスはまだ明らかではないように思われる。

この単一サーバの有効性は、 m -サーバシステムでは、システム内ジョブ数が m 未満のときいわゆる“空き”のサーバが存在していることに起因しているが、 m -サーバシステムにおいて“ジョブが 1 つでもシステム内に存在するときは空きのサーバはない”という規律のもとで、あるいは“空き”のサーバは他へ空伝いに行く”という規律のもとでジョブを処理する場合も単一サーバの有効性が保たれるか否か、という問題が当然生じてくる。

より具体的に述べると、単一サーバシステムと次のように作動する 2-サーバシステムを比較したとき、単一サーバの有効性が保たれるか、否か、の問題である。システムが空の

状態でジョブが到着したとき、2人のサーバでそのジョブを処理する(そのときのサービスレイトは1人のときの2倍)、その処理中に他のジョブが到着したなら、1人のサーバは直ちにその新しいジョブの処理を開始する。2つのジョブの処理中に新しいジョブが到着したなら、それらのジョブは先着順(FIFS)で待つ。もちろん、新しいジョブの到着前に2つのジョブのどちらかの処理が終了したなら、直ちに他のジョブの処理を2人のサーバで行う。

ここで、1つのジョブを2人で処理する際のサービスレイトが1人のときの2倍、という設定はかなり理想的であるかも知れないが、いわゆる“多空きサーバは他へ手伝いに行く”ということは、実際にも数多く見られる。また、上述の2サーバシステムのように作動するmサーバシステムと単一サーバシステムの比較の問題は、計算機のCPUの多重度という観点により自然に解釈できる。すなわち、あるCPUでジョブを1つずつFIFSで処理する場合が単一サーバシステムに相当し、mジョブまではFIFSでタイム・シェアにより処理し、それを超えたとき待ちが生じる場合がmサーバシステムに相当しているわけである。

上述の問題に対して、1つの答えを与えることが本稿の目的である。

2. モデル, 記号

本稿では, 次のように作動する待ち行列システムを扱う。
システム内のスペースを適当に分割して, 前から順に positions
1, 2, ... と番号づける (1つの position には, 1ジョブの
み入ることが出来る)。システム内に n ジョブいるとき,

- (i) 到着したジョブは position $(n+1)$ へ入る (FCFS),
- (ii) 正の整数 m をあらかじめ固定したとき, サーバ (1人

のみ) はそのサービス能力を position j に,

$$\alpha_j(n) (>0), \quad \sum_{j=1}^n \alpha_j(n) = 1 \quad \text{for } n \leq m,$$

$$\alpha_j(n) (>0, j=1, 2, \dots, m), \quad \alpha_j(n) = 0 \quad (j=n+1, \dots, n)$$

$$\sum_{j=1}^m \alpha_j(n) = 1 \quad \text{for } n > m,$$

なる比率 α_j だけふり向ける,

- (iii) position j のジョブの処理が終了したとき, positions

$j+1, j+2, \dots, n$ にいたジョブは, 順に positions $j, j+1, \dots, n-1$ へ移る。

(ii) をより具体的に解釈すると, 上述のようにシステム内を分割したとき, ある固定した m に対し, positions 1, 2, ..., m は service positions となり, positions $m+1, m+2, \dots$ が waiting positions となる (Fig. 1)。このため, 以下では上述のシステムを Limited Processor Sharing Queue (LIPS と略す) と呼び, 特に $m=1$ のときを 1-LIPS, $m(\geq 2)$ を m -LIPS




Fig. 1. Limited Processor Sharing Queue

と呼ぶことにする。

1-LIPS, m -LIPS に対して, 以下では次の記号を用いる。

$L_{\pi}(1)$ = 1-LIPSでの時刻 t におけるシステム内ジョブ数,

$L_{\pi}(m)$ = m -LIPS // ,

$W_{\pi}(1)$ = 1-LIPSでの t における残り仕事量の総和,

$W_{\pi}(m)$ = m -LIPS //

ジョブの処理時間は, i.i.d. r.v.'s での $r.v.$ を S で表わし, その分布関数を $B(\cdot)$ とする。ここでの分布関数の意味は, システム内のサーバが1つのジョブのみの処理に集中したときの確率である。またジョブのシステムへの到着過程は次の条件を満たすものとする (到着間隔が i.i.d. r.v.s である必要がないことに注意)。

[A-1] : 到着過程は処理とは独立で, 有限時間区間内に到着するジョブ数は確率1で有限。

一見, LIPS での (ii) の根拠は抽象的であるが, α_i を適当に設定すると, 次のような通常の待ち行列システムとなる。

例・1 $m=1 \Rightarrow$ FCFS の $G/GI/1$ queue.

例・2 $n \leq m$ のとき $\alpha_j(n) = 1/n$, $n > m$ のとき $\alpha_j(n) = 1/m$ ($j=1, 2, \dots, m$), $\alpha_j(n) = 0$ ($j \geq m+1$) とすると, FCFS の多重度 m のタイムシェア処理の CPU, 特に $m=2$ のときは §1 で述べた “手空きのサーバは他へ手伝いに行く” という 2-サーバシステム。

到着間隔 (i. i. d. r.v's) の分布, $B(x)$ を明示するときには, ケンダールの記号を用いる。例えば, $M/E_2/m$ (LIPS) により, 到着間隔が指数分布, $B(x)$ がフェーズ 2 の m -LIPS を表わす。

3. 基礎的結果

3.1 保存則

ジョブの1-LIPSへの到着時刻列を $\{\tau_i\}_{i=0,1,2,\dots}$ ($\tau_0=0$)とする。相続くジョブの処理時間を S_0, S_1, S_2, \dots としたとき、 $W_\pi(i)$ を図示すると τ_i で S_i だけジャンプし、他では 45° のスロープで減る、いわゆる $G/GI/1$ の待ち時間過程となる。一方、同じジョブが m -LIPSに入るとすると、 $W_\pi(m)$ は τ_i で S_i だけジャンプし、他では 45° のスロープで減る($\sum \alpha_{j,i}=1$ より)ため、 $W_\pi(i)$ と全く一致する。すなわちLIPSは“保存則”が成立するシステムである。さらに、 $L_\pi(m)=0$ なる事象は $W_\pi(m)=0$ と一致するため、 $W_{0-}(i)=W_{0-}(m)$ のとき(便宜上、以上では $W_{0-}(i)=W_{0-}(m)=0$ とする)、次の結果を得る。

定理 1

$W_\pi(i) \stackrel{\text{st}}{=} W_\pi(m), \Pr(L_\pi(i)=0) = \Pr(L_\pi(m)=0),$
 ここで、 $\stackrel{\text{st}}{=}$ は分布の一致を意味する。

3.2 アーラン・サービス

本節では、ジョブの処理時間の分布が k サイズのアーラン分布(E_k ; 1つのフェーズのレイトは $k\mu$)である場合の $L_\pi(i)$ と $L_\pi(m)$ の比較を試みる。

いま, ジョブの到着時点列 $\tau_0, \tau_1, \dots, \tau_{n+1}$ が与えられたときの時刻 t ($\tau_n \leq t < \tau_{n+1}$) における 1-LIPS と m -LIPS の残りフェーズ数の総和 (待, というジョブについては 1 ジョブにつき, 処理中のジョブに関しては, 現在処理中のフェーズを含めた残りフェーズ数) を比較する。般密な議論は省略し直観的な解釈のみを記す。時刻 u ($t < u$) に 1-LIPS に 1 つでもジョブが存在するなら, $[u, u+\Delta u)$ ($\Delta u > 0$) にフェーズ数が 1 つ減る確率は,

$$k_\mu \Delta u + o(\Delta u)$$

で与えられる。 m -LIPS においても, $L_u(m) \geq 1$ なら, $[u, u+\Delta u)$ でフェーズが 1 つ減る確率は,

$$\sum_{j=1}^{L_u(m)} \alpha_j(L_u(m)) k_\mu \Delta u + o(\Delta u) = k_\mu \Delta u + o(\Delta u)$$

となり, 1-LIPS のそれと一致する。到着時点列を両システムで与えていることから, 両システムに到着する総仕事量 (総フェーズ数) の構造は全く一致する。これらの事実と, 定理 1 より両システムで u でシステムが空である確率は等しいことから, 到着に関する条件をはずすことにより, 次の結果を得る。

補助定理. $B(\cdot) = E_R$ のとき, $N_t(1), N_t(m)$ を時刻 t における 1-LIPS, m -LIPS の残りフェーズ数とする。このとき,

$$N_{\pi}(1) \stackrel{st}{=} N_{\pi}(m).$$

この結果を用いて, $L_{\pi}(1)$ と $L_{\pi}(m)$ の比較を試みる。システム内に n ジョブにいるときの 1-LIPS, m -LIPS における残りフェーズ数の総和を, それぞれ $N(1, n)$, $N(m, n)$ で表わす。このとき, 起り得るすべての組合せを考えると, $N(1, n)$, $N(m, n)$ は次の不等式を満たす整数となることが容易に確かめられる。

$$(n-1)k+1 \leq N(1, n) \leq nk,$$

$$\begin{cases} n \leq N(m, n) \leq nk & \text{for } n \leq m \\ (n-m)k+m \leq N(m, n) \leq nk & \text{for } n > m. \end{cases}$$

この不等式から, 残りフェーズ数 N を固定したときの 1-LIPS での可能なジョブ数 $n(1)$ と m -LIPS でのそれ $n(m)$ を求めると次の等号あるいは不等式を満たす整数となる。

$$n(1) = \left\lfloor \frac{N+k-1}{k} \right\rfloor,$$

$$\begin{cases} \left\lfloor \frac{N+k-1}{k} \right\rfloor \leq n(m) \leq N & \text{for } N \leq m, \\ \left\lfloor \frac{N+k-1}{k} \right\rfloor \leq n(m) \leq \left\lfloor \frac{N+m(k-1)}{k} \right\rfloor & \text{for } N > m, \end{cases}$$

ここで任意の実数 a に対して $[a]$ は, a をこえない最大整数 (Gauss の記号) を意味する。すなわち, N を固定したとき $n(1) \leq n(m)$ となり, これと, 上述の補助定理から次の結果を得る。

定理 2. $B(1) = E_2$ を、

$$L_\pi(1) \leq L_\pi(m) \quad \text{for all } \pi,$$

ここで、 \leq は確率的大小関係を示す。

この結果は、LIP 5 でも、通常の複数サーバシステムと単一サーバシステムを比較したときの単一サーバの有効性(33)が保たれることを意味している。 $L_\pi(m-1) \leq L_\pi(m)$ も成立しそうであるが、ここで用いた証明法では得ることができなかった。これについては §4 で数値的に検討する。また、 $L_\pi(1)$ と $L_\pi(m)$ の定量的比較、 μ び処理時間の変動係数 C_s が 1 以上の場合は逆の順序関係となることを、§3.2, §3.3 で例示する。

3.2 M/E₂/2 (LIPS)

到着間隔が指数分布 (レート λ)、ジョブの処理時間の分布がフェーズ 2 のアーラニ分布 (1 のフェーズのレートは 2μ) の 2-LIPS を考える。このシステムの定常状態での平均システム内ジョブ数 $L(2)$ を求めるため、

$$F(z) \triangleq p_0 + p_1 z + p_2 z^2 + \dots,$$

ここで $p_n = \lim_{\pi \rightarrow \infty} p_\pi(L_\pi(2) = n)$, なる母関数 $F(z)$ を導入する。

この $F(z)$ は, P_n に関する平衡方程式から導くことができるが, $\rho_0(1)$ は §2 の例 2 の場合について $F(z)$ を導くと次のようになる (この際 $\rho = \lambda/\mu < 1$, 定理 1 から $P_0 = 1 - \rho$ を用いる)。

$$F(z) = \frac{C(z)}{D(z)} (1 - \rho),$$

$$C(z) = \frac{\rho^3}{2} z^3 - \rho^2(2 + \rho) z^2 + \frac{\rho}{2}(8 + 4\rho + \rho^2) z - 4(2 + \rho),$$

$$D(z) = \rho^3 z^3 - 2\rho^2(3 + \rho) z^2 + \rho(12 + 6\rho + \rho^2) z - 4(2 + \rho).$$

この $F(z)$ から, $L(2) = F'(1)$ として $L(2)$ を求めることができ, それは次式で与えられる。

$$L(2) = \frac{\rho(4 - \rho^2)}{4(1 - \rho)}.$$

一方, この場合の 1-LIPS の平均システム内ジョブ数 (定常状態) $L(1)$ は, $M/E_2/1$ のそれとなるため, 既知の結果から,

$$L(1) = \frac{\rho(4 - \rho)}{4(1 - \rho)}$$

となる。もちろん, $L(2)/L(1) = 1 + \frac{\rho(1 - \rho)}{4 - \rho} > 1$ であるが, この比は $\rho = 0.535 \dots$ で最大となる。すなわち, この場合の単一サーバの有効性は ρ に関して単調ではなく, $\rho = 0.5$ 付近で

それが顕著となることを注意する。

3.3 M/H/2 (LIPS)

到着間隔が指数分布で、 $B(x)$ が次の超指数分布のときの $L(2)$ も内閣数を経て求めることができる。

$$B(x) = \alpha(1 - e^{-2\alpha\mu x}) + (1 - \alpha)(1 - e^{-2(1-\alpha)\mu x}).$$

$\mu_2(1)$ を前節と同様に §2 の例 2 の場合について計算すると、

$$L(2) = L(1) - \varepsilon \quad (\varepsilon > 0),$$

ここで $L(1)$ は 1-LIPS の場合の平均系内ジョブ数である。すなわち、この場合 ($C_s^2 > 1$) は、単一サーバの有効性は成立せず、2-LIPS の方が有効となる。

4. 数値例

m -LIPS の平均システム内ジョブ数を $L(m)$ で表わしたとき、いろいろな場合についてこの数値実験を試み、 $L(m)/L(1)$ についての結果を得ているが、それによると $C_s^2 < 1$ のときは、 $L(m-1) < L(m)$ 、 $C_s^2 > 1$ のときは $L(m-1) > L(m)$ とな

[表・1] $E_5/E_2/m$ (LIPS)

ρ	$L(2)/L(1)$	$L(4)/L(1)$
0.3	1.0149	1.0158
0.5	1.0482	1.0606
0.7	1.0750	1.1257
0.9	1.0518	1.1263

[表・2] $M/H/m$ (LIPS) $C_s^2=3$

ρ	$L(3)/L(1)$	$L(5)/L(1)$
0.3	0.783	
0.5	0.735	0.681
0.7	0.777	0.676
0.9	0.907	0.833

るように思われる。その一例を [表・1], [表・2] で示す。[表・2] の $C_s^2=3$ は, §3.3 の H で m を適当に設定している。すなわち, 処理時間のバラツキが小さい場合は, 単一サーバの方が

有効となるが、バラツキが 大きくなると、 m を増した方が有効となるようである。

5. お わ り に

LIPSにおける m の増加が待ちにどのような影響を与えるかについて、若干の部分的結果を得ることができた。しかしながら、§2の方法は、フェーズの特性に強く依存していて他の分布のクラスについては適用が難しく、また $L_x(m-1)$ と $L_x(m)$ の比較もできなかった。数値結果によらず、 $L_x(m-1) \geq L_x(m)$ となるようであるが、これは今後の課題である。

また図1についての特性の解析は、 $M/H/2$ (LIPS)のみで、数値実験の結果に頼らざるを得なかったが、最近B(i)がNWレであるとき、すなわち $\bar{B}(x)\bar{B}(y) \leq \bar{B}(x+y)$ のとき $L_x(1) \geq L_x(m)$ となることが証明されたことを付記する(Yamazaki [4])。

ゆい) については、数値実験等では §2の例・2の場合についてのみ扱っているが、§3.2の結果はゆい)には依存しないし、また[4]の結果も同様である。ここでは、FLFSのLIPSのみを扱ったが、サーバの能力を各 position に確率的に振り分け、ジョブの各 position への入るのも確率的に定めた

ときも同様の結果が成立する (Kelly [2] はこれらの確率は等しい場合を扱ったが、ここでは独立に定めてもよい)。

References

1. Brumelle, S. L., "Some inequalities for parallel service queues," *Opns. Res.*, 19 (1971).
2. Kelly, F. P., "Networks of queues," *Adv. Appl. Prob.*, 8 (1976).
3. Stidham, S. Jr., "On the optimality of single-server queueing systems," *Opns. Res.*, 18 (1970).
4. 山崎, "LIPSにおける確率的順序関係," 日本OR学会春季研究発表会 (1984, 予定).